15 | 数据源与数据格式：DataFrame从何而来？

2021-10-13 吴磊

《零基础入门Spark》 课程介绍 >

讲述：吴磊
时长 24:53 大小 22.79M

你好，我是吴磊。

在上一讲，我们重点讲解了 DataFrame 与 Spark SQL 的渊源，并提到，DataFrame 是 Spark SQL 的重要入口。换句话说，通过创建 DataFrame 并沿用 DataFrame 开发 API，我们才能充分利用 Spark SQL 优化引擎提供种种“性能红利”。显然，对于初学者来说，第一步的创建 DataFrame 就变得至关重要。

之前13 讲，我们做小汽车摇号倍率分析时，用了 SparkSession 的 read API 从 Parquet 文件创建 DataFrame，其实创建 DataFrame 的方法还有很多。毫不夸张地说，DataFrame 的创建途径异常丰富，为什么这么说呢？

如下图所示，Spark 支持多种数据源，按照数据来源进行划分，这些数据源可以分为如下几个大类：Driver 端自定义的数据结构、（分布式）文件系统、关系型数据库 RDBMS、关系型数据仓库、NoSQL 数据库，以及其他的计算引擎。

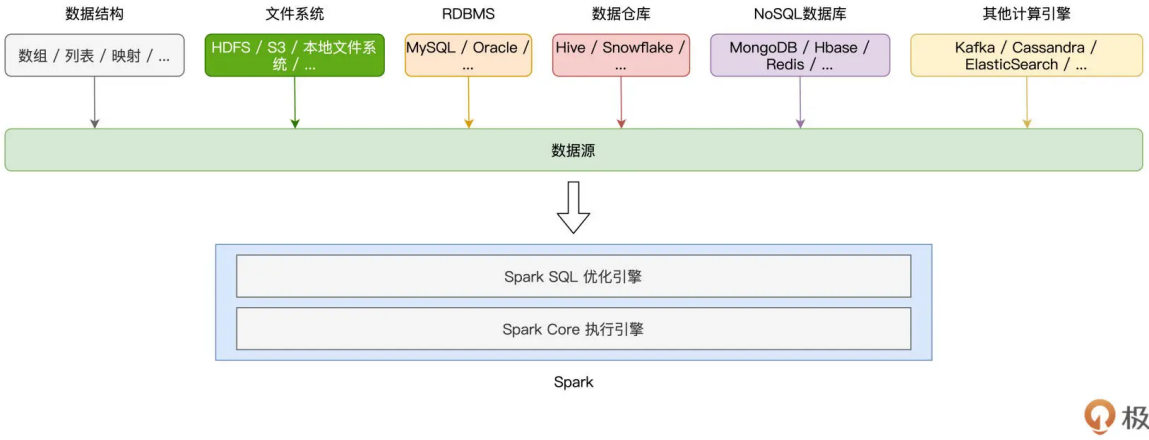

Spark支持的数据源

显然，要深入地介绍 Spark 与每一种数据源的集成并不现实，也没必要，咱们只需要把注意力放在那些最常用、最常见的集成方式即可。

这一讲，我会从 Driver、文件系统与 RDBMS 三个方面，为你讲解 5 种常见的 DataFrame 创建方式，然后带你了解不同方式的使用场景跟优劣分析。

从 Driver 创建 DataFrame

在 Driver 端，Spark 可以直接从数组、元组、映射等数据结构创建 DataFrame。使用这种方式创建的 DataFrame 通常数据量有限，因此这样的 DataFrame 往往不直接参与分布式计算，而是用于辅助计算或是数据探索。尽管如此，学习这部分知识点还是非常必要的，因为它可以帮我们更直观地理解 DataFrame 与 RDD 的关系。

还记得吗？在数据表示（Data Representation）上，相比 RDD，DataFrame 仅仅是多了一个 Schema。甚至可以说，DataFrame 就是带 Schema 的 RDD。因此，创建 DataFrame 的第一种方法，就是先创建 RDD，然后再给它“扣上”一顶 Schema 的“帽子”。

从本地数据结构创建 RDD，我们用的是 SparkContext 的 parallelize 方法，而给 RDD“扣帽子”，我们要用到 SparkSession 的 createDataFrame 方法。

createDataFrame 方法

为了创建 RDD，我们先来定义列表数据 seq。seq 的每个元素都是二元元组，元组第一个元素的类型是 String，第二个元素的类型是 Int。有了列表数据结构，接下来我们创建 RDD，如下所示。

复制代码

```
import org.apache.spark.rdd.RDD
val seq: Seq[(String, Int)] = Seq(("Bob", 14), ("Alice", 18))
val rdd: RDD[(String, Int)] = sc.parallelize(seq)
```

有了 RDD 之后，我们来给它制作一顶“帽子”，也就是我们刚刚说的 Schema。创建 Schema，我们需要用到 Spark SQL 内置的几种类型，如 StructType、StructField、StringType、IntegerType，等等。

其中，StructType 用于定义并封装 Schema，StructFiled 用于定义 Schema 中的每一个字段，包括字段名、字段类型，而像 StringType、IntegerType 这些 *Type 类型，表示的正是字段类型。为了和 RDD 数据类型保持一致，Schema 对应的元素类型应该是（StringType，IntegerType）。

复制代码

```
import org.apache.spark.sql.types.{StringType, IntegerType, StructField, Struc
val schema:StructType = StructType( Array(
StructField("name", StringType),
StructField("age", IntegerType)
))
```

好啦，到此为止，我们有了 RDD，也有了为它量身定做的“帽子”Schema。不过，在把帽子扣上去之前，我们还要先给 RDD 整理下“发型”。这是什么意思呢？

createDataFrame 方法有两个形参，第一个参数正是 RDD，第二个参数是 Schema。createDataFrame 要求 RDD 的类型必须是 RDD[Row]，其中的 Row 是 org.apache.spark.sql.Row，因此，对于类型为 RDD[(String, Int)]的 rdd，我们需要把它转换为 RDD[Row]。

```
import org.apache.spark.sql.Row
val rowRDD: RDD[Row] = rdd.map(fileds => Row(fileds._1, fileds._2))
```

复制代码

“发型”整理好之后，我们就可以调用 createDataFrame 来创建 DataFrame，代码如下所示。

```
import org.apache.spark.sql.DataFrame
val dataFrame: DataFrame = spark.createDataFrame(rowRDD,schema)
```

复制代码

DataFrame 创建好之后，别忘了验证它的可用性，我们可以通过调用 show 方法来做简单的数据探索，验证 DataFrame 创建是否成功。

```
dataFrame.show

/** 结果显示
+----+---+
| name| age|
+----+---+
| Bob| 14|
| Alice| 18|
+----+---+
*/
```

复制代码

历尽千辛万苦，我们先是用 Driver 端数据结构创建 RDD，然后再调用 createDataFrame 把 RDD 转化为 DataFrame。你可能会说：“相比用 parallelize 创建 RDD，用 createDataFrame 创建 DataFrame 的方法未免复杂了些，有没有更简便的方法呢？”我们接着往下看。

toDF 方法

其实要把 RDD 转化为 DataFrame，我们并不一定非要亲自制作 Schema 这顶帽子，还可以直接在 RDD 之后调用 toDF 方法来做到这一点。咱们先来看 toDF 函数的用法，然后再去分析，spark.implicits 是如何帮我们轻松创建 DataFrame 的。

复制代码

```
import spark.implicits._
val dataFrame: DataFrame = rdd.toDF
dataFrame.printSchema
/** Schema显示
root
|-- _1: string (nullable = true)
|-- _2: integer (nullable = false)
*/
```

可以看到，我们显示导入了 spark.implicits 包中的所有方法，然后通过在 RDD 之上调用 toDF 就能轻松创建 DataFrame。实际上，利用 spark.implicits，我们甚至可以跳过创建 RDD 这一步，直接通过 seq 列表来创建 DataFrame。

复制代码

```
import spark.implicits._
val dataFrame: DataFrame = seq.toDF
dataFrame.printSchema
/** Schema显示
root
|-- _1: string (nullable = true)
|-- _2: integer (nullable = false)
*/
```

是不是感觉这个方法很简洁、很轻松？不过，你可能会问：“既然有 toDF 这条捷径，一开始干嘛还要花功夫去学步骤繁琐的 createDataFrame 方法呢？”

网络上流行过这么一句话：“你的岁月静好，是有人在背后帮你负重前行。” toDF 也是同样的道理，我们之所以能用 toDF 轻松创建 DataFrame，关键在于 spark.implicits 这个包提供了各种隐式方法。

隐式方法是 Scala 语言中一类特殊的函数，这类函数不需要开发者显示调用，函数体中的计算逻辑在适当的时候会自动触发。正是它们在背后默默地帮我们用 seq 创建出 RDD，再用 createDataFrame 方法把 RDD 转化为 DataFrame。

从文件系统创建 DataFrame

说完第一类数据源，接下来，我们再来看看 Spark 如何从文件系统创建 DataFrame。

Spark 支持多种文件系统，常见的有 HDFS、Amazon S3、本地文件系统，等等。不过无论哪种文件系统，Spark 都要通过 SparkSession 的 read API 来读取数据并创建 DataFrame。所以接下来，我们需要先弄明白 read API 要怎样使用，都有哪些注意事项。

read API 由 SparkSession 提供，它允许开发者以统一的形式来创建 DataFrame，如下图所示。

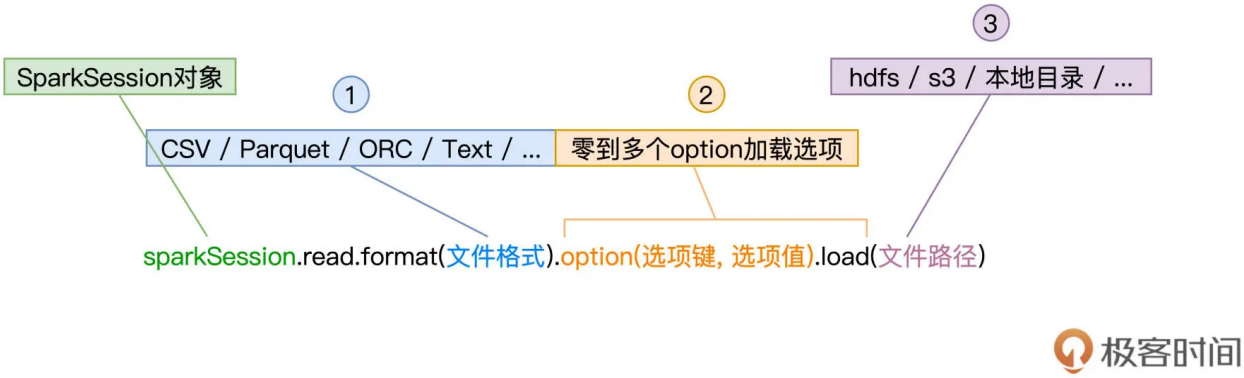

read API统一入口

可以看到，要使用 read API 创建 DataFrame，开发者只需要调用 SparkSession 的 read 方法，同时提供 3 类参数即可。这 3 类参数分别是文件格式、加载选项和文件路径，它们分别由函数 format、option 和 load 来指定。

先来看第 1 类参数文件格式，它就是文件的存储格式，如 CSV（Comma Separated Values）、Text、Parquet、ORC、JSON。Spark SQL 支持种类丰富的文件格式，除了这里列出的几个例子外，Spark SQL 还支持像 Zip 压缩文件、甚至是图片 Image 格式。

完整的格式支持，你可以参考下图，或是访问官网给出的列表。在后续的讲解中，我们还会挑选一些常用的数据格式来演示 read API 的具体用法。

read API支持的数据格式

文件格式决定了第 2 类参数加载选项的可选集合，也就是说，不同的数据格式，可用的选型有所不同。比如，CSV 文件格式可以通过 option（“header”，true)，来表明 CSV 文件的首行为 Data Schema，但其他文件格式就没有这个选型。之后讲到常见文件格式用法时，我们再对其加载选项做具体讲解。

值得一提的是，加载选项可以有零个或是多个，当需要指定多个选项时，我们可以用“option(选项 1, 值 1).option(选项 2, 值 2)”的方式来实现。

read API 的第 3 类参数是文件路径，这个参数很好理解，它就是文件系统上的文件定位符。比如本地文件系统中的“/dataSources/wikiOfSpark.txt”，HDFS 分布式文件系统中的“hdfs://hostname:port/myFiles/userProfiles.csv”，或是 Amazon S3 上的“s3://myBucket/myProject/myFiles/results.parquet”，等等。

了解了 read API 的一般用法之后，接下来，我们结合一些常见的数据格式，来进行举例说明。对于那些在这节课没有展开介绍的文件格式，你可以参考官网给出的用法来做开发。

从 CSV 创建 DataFrame

以可读性好的纯文本方式来存储结构化数据，CSV 文件格式的身影常见于数据探索、数据分析、机器学习等应用场景。经过上面的分析，我们知道，要从 CSV 文件成功地创建 DataFrame，关键在于了解并熟悉与之有关的加载选项。那么我们就来看看，CSV 格式都有哪些对应的 option，它们的含义都是什么。

加载选项	可选值	默认值	含义
header	true, false	FALSE	CSV文件的第一行，是否为Data Schema
seq	任意字符	，（逗号）	数据列之间的分隔符
escape	任意字符	\（反斜杠）	转义字符
nullValue	任意字符	“”（空字符串）	声明文件中的空值
dateFormat	SimpleDateFormat字符串	yyyy-MM-dd	声明日期格式
mode	permissive, dropMalformed, failFast	permissive	读取模式

极客时间

CSV格式常用的option选项

从上往下看，首先是“header”，header 的设置值为布尔值，也即 true 或 false，它用于指定 CSV 文件的首行是否为列名。如果是的话，那么 Spark SQL 将使用首行的列名来创建 DataFrame，否则使用“_c”加序号的方式来命名每一个数据列，比如“_c0”、“_c1”，等等。

对于加载的每一列数据，不论数据列本身的含义是什么，Spark SQL 都会将其视为 String 类型。例如，对于后面这个 CSV 文件，Spark SQL 将“name”和“age”两个字段都视为 String 类型。

复制代码

```
name,age
alice,18
bob,14
```

CSV 文件内容

复制代码

```
import org.apache.spark.sql.DataFrame
val csvFilePath: String = _
val df: DataFrame = spark.read.format("csv").option("header", true).load(csvFi
// df: org.apache.spark.sql.DataFrame = [name: string, age: string]
df.show
/** 结果打印
+-----+---+
| name| age|
+-----+---+
| alice| 18|
| bob| 14|
+-----+---+
*/
```

数据列默认数据类型都是 String

要想在加载的过程中，为 DataFrame 的每一列指定数据类型，我们需要显式地定义 Data Schema，并在 read API 中通过调用 schema 方法，来将 Schema 传递给 Spark SQL。

Data Schema 的定义我们讲 createDataFrame 函数的时候提过，咱们不妨一起来回顾一下。

```
import org.apache.spark.sql.types.{StringType, IntegerType, StructField, Struc
val schema:StructType = StructType( Array(
StructField("name", StringType),
StructField("age", IntegerType)
))
```

定义 Schema

```
val csvFilePath: String = _
val df: DataFrame = spark.read.format("csv").schema(schema).option("header", t
// df: org.apache.spark.sql.DataFrame = [name: string, age: int]
```

调用 schema 方法来传递 Data Schema

可以看到，在使用 schema 方法明确了 Data Schema 以后，数据加载完成之后创建的 DataFrame 类型由原来的“[name: string, age: string]”，变为“[name: string, age: int]”。需要注意的是，**并不是所有文件格式都需要 schema 方法来指定 Data Schema**，因此在 read API 的一般用法中，schema 方法并不是必需环节。

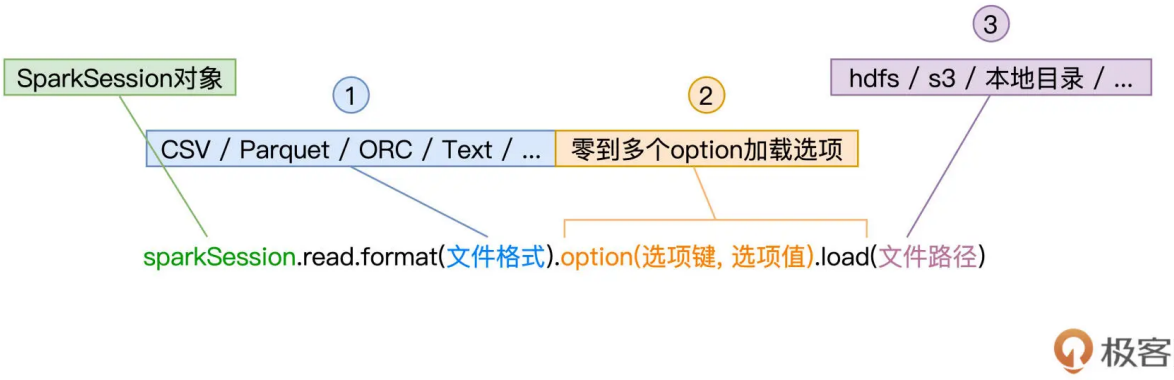

read API的一般用法

好，我们接着说 CSV 格式的 option 选项。在“header”之后，第二个选项是“seq”，它是用于分隔列数据的分隔符，可以是任意字符串，默认值是逗号。常见的分隔符还有

Tab、“|”，等等。

之后的“escape”和“nullValue”分别用于指定文件中的转义字符和空值，而“dateFormat”则用于指定日期格式，它的设置值是任意可以转换为 Java SimpleDateFormat 类型的字符串，默认值是“yyyy-MM-dd”。

最后一个选项是“mode”，它用来指定文件的读取模式，更准确地说，它明确了 Spark SQL 应该如何对待 CSV 文件中的“脏数据”。

所谓脏数据，它指的是数据值与预期数据类型不符的数据记录。比如说，CSV 文件中有一列名为“age”数据，它用于记录用户年龄，数据类型为整型 Int。那么显然，age 列数据不能出现像“8.5”这样的小数、或是像“8 岁”这样的字符串，这里的“8.5”或是“8 岁”就是我们常说的脏数据。

在不调用 schema 方法来显示指定 Data Schema 的情况下，Spark SQL 将所有数据列都看作是 String 类型。我们不难发现，mode 选项的使用，往往会与 schema 方法的调用如影随形。

mode 支持 3 个取值，分别是 permissive、dropMalformed 和 failFast，它们的含义如下表所示。

mode取值	含义
permissive	容忍度最高：遇到脏数据，将脏数据替换为null，正常加载数据并创建DataFrame
dropMalformed	有的商量：遇到脏数据则跳过加载，不让它进入待创建的DataFrame，其他数据则正常加载
failFast	任性：遇到脏数据立即报错并退出，创建DataFrame失败

极客时间

mode取值与含义

可以看到，除了“failFast”模式以外，另外两个模式都不影响 DataFrame 的创建。以下面的 CSV 文件为例，要想剔除脏数据，也就是“cassie, six”这条记录，同时正常加载满足类型要求的“干净”数据，我们需要同时结合 schema 方法与 mode 选项来实现。

复制代码

```
name,age
alice,18
bob,14
cassie, six
```

CSV 文件内容

复制代码

```
val csvFilePath: String = _
val df: DataFrame = spark.read.format("csv")
.schema(schema)
.option("header", true)
.option("mode", "dropMalformed")
.load(csvFilePath)
// df: org.apache.spark.sql.DataFrame = [name: string, age: int]
df.show
/** 结果打印
+-----+---+
| name| age|
+-----+---+
| alice| 18|
| bob| 14|
+-----+---+
*/
```

调用 schema 方法来传递 Data Schema

好啦，关于从 CSV 文件创建 DataFrame，我们就讲完了。不难发现，从 CSV 创建 DataFrame，过程相对比较繁琐，开发者需要注意的细节也很多。不过，毕竟 CSV 简单直接、跨平台、可读性好、应用广泛，因此掌握这部分开发技巧，还是非常值得的。

从 Parquet / ORC 创建 DataFrame

接下来，我们就来说说 Parquet 格式和 ORC 格式，相比从 CSV 创建 DataFrame，这两个方法就没那么麻烦了。

Parquet 与 ORC，都是应用广泛的列存（Column-based Store）文件格式。顾名思义，列存，是相对行存（Row-based Store）而言的。

在传统的行存文件格式中，数据记录以行为单位进行存储。虽然这非常符合人类的直觉，但在数据的检索与扫描方面，行存数据往往效率低下。例如，在数据探索、数据分析等数仓应用场景中，我们往往仅需扫描数据记录的某些字段，但在行存模式下，我们必须要扫描全量数据，才能完成字段的过滤。

CSV 就是典型的行存数据格式，以如下的内容为例，如果我们想要统计文件中女生的数量，那么我们不得不扫描每一行数据，判断 gender 的取值，然后才能决定是否让当前记录参与计数。

复制代码

```
1 name,age,gender
2 alice,18,female
3 bob,14,male
```

CSV 文件内容

列存文件则不同，它以列为单位，对数据进行存储，每一列都有单独的文件或是文件块。还是以上面的文件内容为例，如果采用列存格式的话，那么文件的存储方式将会变成下面的样子。

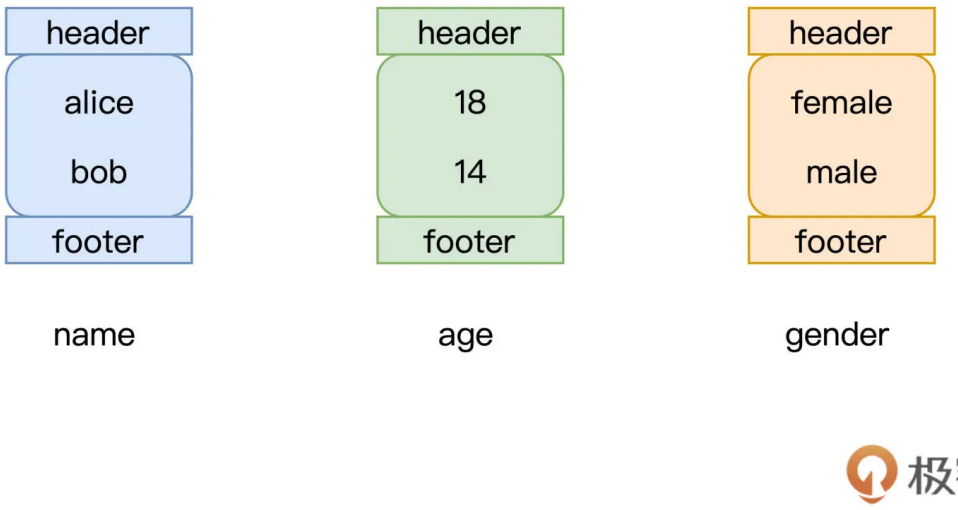

列存文件格式示意图

可以看到，数据按列存储，想要统计女生的数量，我们只需扫描 gender 列的数据文件，而不必扫描 name 与 age 字段的数据文件。相比行存，列存有利于大幅削减数据扫描所需

的文件数量。

不仅如此，对于每一个列存文件或是文件块，列存格式往往会附加 header 和 footer 等数据结构，来记录列数据的统计信息，比如最大值、最小值、记录统计个数，等等。这些统计信息会进一步帮助提升数据访问效率，例如，对于 max=“male”同时 min=“male”的 gender 文件来说，在统计女生计数的时候，我们完全可以把这样的文件跳过，不进行扫描。

再者，很多列存格式往往在文件中记录 Data Schema，比如 Parquet 和 ORC，它们会利用 Meta Data 数据结构，来记录所存储数据的数据模式。这样一来，在读取类似列存文件时，我们无需再像读取 CSV 一样，去手工指定 Data Schema，这些繁琐的步骤都可以省去。因此，使用 read API 来读取 Parquet 或是 ORC 文件，就会变得非常轻松，如下所示。

复制代码

```
val parquetFilePath: String = _
val df: DataFrame = spark.read.format("parquet").load(parquetFilePath)
```

使用 read API 读取 Parquet 文件

复制代码

```
val orcFilePath: String = _
val df: DataFrame = spark.read.format("orc").load(orcFilePath)
```

使用 read API 读取 ORC 文件

可以看到，在 read API 的用法中，我们甚至不需要指定任何 option，只要有 format 和 load 这两个必需环节即可。是不是非常简单？

好啦，到此为止，我们梳理了如何从文件系统，在不同的数据格式下创建 DataFrame。在这一讲的最后，我们再来简单地了解一下如何从关系型数据库创建 DataFrame，毕竟，这个场景在我们日常的开发中还是蛮常见的。

从 RDBMS 创建 DataFrame

使用 read API 读取数据库，就像是使用命令行连接数据库那么简单。而使用命令行连接数据库，我们往往需要通过参数来指定数据库驱动、数据库地址、用户名、密码等关键信息。read API 也是一样，只不过，这些参数通通由 option 选项来指定，以 MySQL 为例，read API 的使用方法如下。

复制代码

```
spark.read.format("jdbc")
.option("driver", "com.mysql.jdbc.Driver")
.option("url", "jdbc:mysql://hostname:port/mysql")
.option("user", "用户名")
.option("password","密码")
.option("numPartitions", 20)
.option("dbtable", "数据表名 ")
.load()
```

使用 read API 连接数据库并创建 DataFrame

访问数据库，我们同样需要 format 方法来指定“数据源格式”，这里的关键字是“jdbc”。请注意，由于数据库 URL 通过 option 来指定，因此调用 load 方法不再需要传入“文件路径”，我们重点来关注 option 选项的设置。

与命令行一样，option 选项同样需要 driver、url、user、password 这些参数，来指定数据库连接的常规设置。不过，毕竟调用 read API 的目的是创建 DataFrame，因此，我们还需要指定“dbtable”选项来确定要访问哪个数据表。

有意思的是，除了将表名赋值给“dbtable”以外，我们还可以把任意的 SQL 查询语句赋值给该选项，这样在数据加载的过程中就能完成数据过滤，提升访问效率。例如，我们想从 users 表选出所有的女生数据，然后在其上创建 DataFrame。

复制代码

```
val sqlQuery: String = “select * from users where gender = ‘female’”
spark.read.format("jdbc")
.option("driver", "com.mysql.jdbc.Driver")
.option("url", "jdbc:mysql://hostname:port/mysql")
.option("user", "用户名")
.option("password","密码")
.option("numPartitions", 20)
.option("dbtable", sqlQuery)
.load()
```

为 dbtable 选项赋值 SQL 语句

此外，为了提升后续的并行处理效率，我们还可以通过“numPartitions”选项来控制 DataFrame 的并行度，也即 DataFrame 的 Partitions 数量。

需要额外注意的是，在默认情况下，Spark 安装目录并没有提供与数据库连接有关的任何 Jar 包，因此，对于想要访问的数据库，不论是 MySQL、PostgreSQL，还是 Oracle、DB2，我们都需要把相关 Jar 包手工拷贝到 Spark 安装目录下的 Jars 文件夹。与此同时，我们还要在 spark-shell 命令或是 spark-submit 中，通过如下两个命令行参数，来告诉 Spark 相关 Jar 包的访问地址。

–driver-class-path mysql-connector-java-version.jar

–jars mysql-connector-java-version.jar

好啦，到此为止，这一讲的内容就全部讲完啦！今天的内容有点多，我们来一起总结一下。

重点回顾

今天这一讲，我们聚焦在 DataFrame 的创建方式上。Spark 支持种类丰富的数据源与数据格式，我们今天的重点，是通过 Driver、文件系统和关系型数据库，来创建 DataFrame。

在 Driver 端，我们可以使用 createDataFrame 方法来创建 DataFrame，需要注意的是，这种创建方式有两个前提条件。**一是底层 RDD 的类型必须是 RDD[Row]，二是我们需要手工创建 Data Schema**。Schema 的创建需要用到 StructType、StructField 等数据类型，你要牢记在心。

复制代码

```
import org.apache.spark.sql.types.{StringType, IntegerType, StructField, Struc
val schema:StructType = StructType( Array(
StructField("name", StringType),
StructField("age", IntegerType)
))
```

定义 Schema

除了这种比较繁琐的方式之外，我们还可以利用 spark.implicits._ 提供的隐式方法，通过在 RDD 或是原始序列数据之上调用 toDF 方法，轻松创建 DataFrame。

接着，使用 SparkSession 的 read API，我们分别讲解了从 CSV、Parquet、ORC 和关系型数据库创建 DataFrame 的一般方法。read API 调用的一般方法，需要你熟练掌握。

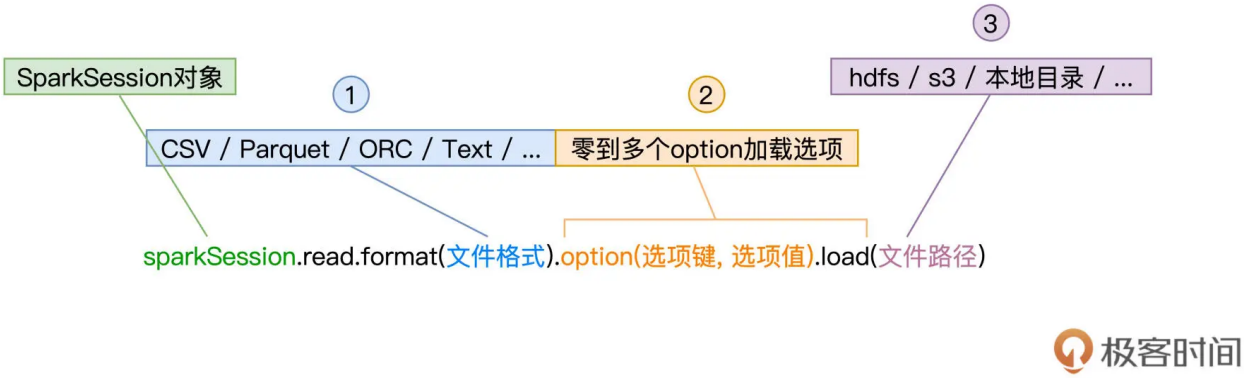

read API的一般用法

由于 Parquet、ORC 这类列存格式在文件中内置了 Data Schema，因此，访问这类文件格式，只有 format 和 load 两个方法是必需的。

相比之下，读取 CSV 较为复杂。首先，为了指定 Data Schema，开发者需要额外通过 schema 方法，来输入预定义的数据模式。再者，CSV 的 option 选项比较多，你可以参考后面的表格，来更好地控制 CSV 数据的加载过程。

加载选项	可选值	默认值	含义
header	true, false	FALSE	CSV文件的第一行，是否为Data Schema
seq	任意字符	，（逗号）	数据列之间的分隔符
escape	任意字符	\（反斜杠）	转义字符
nullValue	任意字符	“”（空字符串）	声明文件中的空值
dateFormat	SimpleDateFormat字符串	yyyy-MM-dd	声明日期格式
mode	permissive, dropMalformed, failFast	permissive	读取模式

极客时间

CSV格式常用的option选项

最后，我们学习了 read API 访问 RDBMS 的一般方法。与命令行的访问方式类似，你需要通过多个 option 选项，来指定数据库连接所必需的访问参数，如数据库驱动、URL 地址、用户名、密码，等等。特别地，你还可以为“dbtable”选项指定表名或是查询语句，对数据的加载过程进行干预和控制。

每课一练

给定如下 CSV 文件，请你分别使用 permissive, dropMalformed, failFast 这 3 种 mode，对比 read API 所创建的 DataFrame 之间的区别。

复制代码

```
name,age
alice,18
bob,14
cassie, six
```

欢迎你在留言区跟我交流活动，也推荐你把这一讲的内容分享给更多的同事、朋友，跟他一起学习进步。

分享给需要的人，Ta订阅后你可得 20 元现金奖励

生成海报并分享

赞 3　提建议

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇　14 | DataFrame与Spark SQL的由来

下一篇　16 | 数据转换：如何在DataFrame之上做数据处理？

精选留言 (2)

写留言

AIK
2021-10-13

老师，感觉最近更新的Spark SQL没有Spark core有深度了？是我直觉性错误，还是我没有get到老师聊的点呢

展开

作者回复: 其实入门课的4部分，深度都没有太深，主要是考虑确实有不少零基础的同学，需要照顾到~

老弟有这种感觉，说明你Spark SQL的底子比较好，哈哈

性能篇的话，会深入很多，其实也是因为很多同学反馈性能篇难度偏高，我这边才会考虑出个入门篇，去满足不同同学的需求。

确实，入门篇对于不少同学来说，可能会偏浅，先跟老弟说声抱歉吧。不过也是好事，说明老弟在Spark这方面还是有不少积累的~

czuo03

2021-10-13

permissive会将six替换为null
val df: DataFrame = spark.read.format("csv").schema(schema).option("header", true).option("mode", "permissive").load(csvFilePath)
+------+----+
| name| age|...
展开

作者回复: 赞👍，满分💯！